

Metody regionální segmentace pro identifikaci objektů zájmu z medicínských obrazů–laboratorní úloha

Regional Segmentation Methods for Objects of Interest
Identification from Medical Images–A Laboratory Task

Matouš Vondál

Bakalářská práce

Vedoucí práce: Ing. Jan Kubíček, Ph.D

Ostrava, 2021

Poděkování

Především bych chtěl poděkovat panu Ing. Janu Kubíčkovi, Ph.D, za cenné rady a připomínky k vypracování této práce a veškerý čas, který mi věnoval. V neposlední řadě bych chtěla poděkovat celé mé rodině, přítelkyni a přátelům za podporu při studiu.

Abstrakt

Vizuální obrazová informace hraje důležitou roli téměř ve všech oblastech našeho života. V dnešní době je většina těchto informací reprezentována v digitální formě obrazu. Toto zobrazování je všude přítomné od televizního obrazu, přes digitální fotografie, až po snímky CT. Tato práce se bude zabývat předzpracováním a následnou segmentací medicínských obrazů. Medicínské obrazy budou obsahovat záznamy z oblasti CT a MRI. Cílem této práce je aplikace předzpracování obrazu pomocí mediánové filtrace a následné použití metod Otsu prahování a K-means shlukování. Dosažené výsledky se použijí na zhodnocení výkonosti jednotlivých metod. Výkonost metod se bude hodnotit pomocí evaluačních parametrů. Použity budou parametry MSE, PSNR a index korelace. Celá práce je řešena v prostředí MATLAB. Z výsledné analýzy se získají důležité informace o vlastnostech vybraných metod. Práce bude zakončena návrhem vlastní laboratorní úlohy.

Klíčová slova

Prahování Otsu, shlukování K-means, mediánová filtrace, segmentace

Abstract

Visual imaging information plays a fundamental role in almost every aspect of our lives. Nowadays, most of this information presents itself the digital form of an image. This kind of imagery is ubiquitous, from a television picture, digital photographs to a CT image. The thesis deals with pretreatment and the following segmentation of medical images. Medical images include footage from CT and MRI. The aim of the thesis is to evaluate the pretreatment image application using the median filter technique, successive by the usage of Otsu thresholding and K-means clustering methods. Attained results will be used for an efficient evaluation of each method used. The efficiency of the methods will be evaluated via evaluation parameters. MSE, PSNR, and a correlation coefficient will be used as the parameters for the evaluation. The entire thesis makes use of the MATLAB software. The final analysis processes the important information relating to the features of the method used. The thesis ends with the proposition of an educational laboratory task.

Keywords

Otsu thresholding, K-means clustering, the median filter, segmentation

Obsah

| | |
|---|----|
| Seznam použitých zkratk a symbolů..... | 7 |
| Seznam obrázků..... | 8 |
| Seznam tabulek | 11 |
| Úvod | 12 |
| 1 Základní principy zpracování medicínských obrazových dat..... | 13 |
| 1.1 Definice obrazu..... | 13 |
| 1.2 Postup zpracování | 13 |
| 1.3 Snímání obrazu | 14 |
| 1.4 Digitalizace..... | 14 |
| 1.5 Předzpracování obrazu | 15 |
| 1.6 Segmentace | 15 |
| 1.7 Klasifikace | 17 |
| 1.7.1 Příznakové rozpoznávání..... | 17 |
| 1.7.2 Strukturální rozpoznávání | 17 |
| 2 Základní procedury předzpracování obrazových dat | 17 |
| 2.1 Jasová transformace..... | 17 |
| 2.1.1 Transformace jasové stupnice..... | 18 |
| 2.1.2 Jasová korekce..... | 19 |
| 2.2 Geometrická transformace | 19 |
| 2.2.1 Transformace souřadnic bodů | 20 |
| 2.2.2 Aproximace jasové funkce..... | 21 |
| 2.2.3 Metoda nejbližšího souseda..... | 21 |
| 2.2.4 Lineární interpolace..... | 21 |
| 2.2.5 Bikubická interpolace | 22 |

| | | |
|-------|---|----|
| 2.3 | Filtrace a ošetření..... | 22 |
| 2.3.1 | Diskrétní konvoluce..... | 22 |
| 2.3.2 | Vyhlazování průměrováním | 23 |
| 2.3.3 | Mediánová filtrace | 23 |
| 3 | Komplexní řešení regionální segmentace s orientací na identifikaci zájmových oblastí. | 24 |
| 3.1 | Prahování (Thresholding) | 24 |
| 3.2 | Narůstání oblastí (Region – growing) | 25 |
| 3.3 | Dělení a spojování (Split and merge)..... | 26 |
| 3.4 | Shluková analýza | 27 |
| 3.4.1 | Algoritmus (K-means)..... | 28 |
| 3.5 | Závěr řešení | 28 |
| 4 | Praktická část..... | 29 |
| 4.1 | Databáze medicínských obrazů | 29 |
| 4.2 | Zašumění obrazu | 30 |
| 4.2.1 | Gaussův šum..... | 30 |
| 4.2.2 | Salt and Pepper (šum sůl a pepř) | 31 |
| 4.2.3 | Speckle šum..... | 32 |
| 4.3 | Předzpracování obrazových dat | 32 |
| 4.3.1 | Mediánová filtrace | 33 |
| 4.4 | Implementace jednotlivých segmentačních metod | 33 |
| 4.4.1 | Otsu prahování..... | 34 |
| 4.4.2 | Shlukování pomocí K-means | 35 |
| 4.5 | Evaluační parametry pro analýzu podobnosti..... | 36 |
| 4.5.1 | Střední kvadratická chyba (MSE)..... | 37 |
| 4.5.2 | Špičkový odstup od šumu (PSNR)..... | 37 |

| | | |
|-------|--|----|
| 4.5.3 | Korelační koeficient..... | 37 |
| 4.6 | Testování metod na medicínských datech | 38 |
| 4.6.1 | Výsledky CT-cévy | 38 |
| 4.6.2 | Výsledky MRI-cévy..... | 41 |
| 4.6.3 | Výsledky CT-játra | 44 |
| 4.6.4 | Výsledky MRI-chrupavky | 47 |
| 4.6.5 | Vyhodnocení testování..... | 50 |
| | Závěr | 51 |
| | Literatura | 52 |
| | Seznam příloh | 54 |

Seznam použitých zkratek a symbolů

| | |
|------------|---------------------------|
| Σ | Suma |
| \int | Integrál |
| % | Procento |
| \cap | Průnik |
| U | Sjednocení |
| 2D | Dvoudimenzionální |
| 3D | Třidimenzionální |
| MSE | Střední kvadratická chyba |
| PSNR | Špičkový odstup od šumu |
| dB | Decibel |
| MRI | Magnetická rezonance |
| CT | Výpočetní tomografie |
| σ^2 | Rozptyl |
| μ | Střední hodnota |

Seznam obrázků

| | |
|--|----|
| Obrázek 1 Schéma postupu pro zpracování obrazu [22]. | 14 |
| Obrázek 2 Čtvercová a hexagonální vzorkovací mřížka Upraveno dle [5]. | 15 |
| Obrázek 3 a)MRA snímek segmentace tepen b) segmentace cévního systému c)segmentované tepny Upraveno dle [9]...... | 16 |
| Obrázek 4 Zvýšení kontrastu po ekvalizaci histogramu. [24] | 18 |
| Obrázek 5 Schéma jasové korekce. [23]..... | 19 |
| Obrázek 6 Princip konvoluce Upraveno dle [6]. | 22 |
| Obrázek 7 a) nativní snímek, b) snímek s vyšším nastaveným prahem, c) snímek s nižším nastaveným prahem, d) snímek s optimálně zvoleným prahem. Upraveno dle [18]...... | 24 |
| Obrázek 8 Adaptivní prahování. A) původní obrázek. B) globální prahování. C) rozdělení na pod obrazy. D) segmentace jednotlivých pod obrazů. Upraveno dle [1]..... | 25 |
| Obrázek 9 a) poloha výchozích bodů b) narůstání oblastí c) výsledek segmentace. Upraveno dle [10]. | 26 |
| Obrázek 10 Schéma metody dělení a slučování Upraveno dle [1]. | 26 |
| Obrázek 11 Výsledky shlukování pro: a) správný počet shluků se všemi body správně klasifikovanými b) nesprávný počet shluků c) správný počet shluků, ale některé body nesprávně klasifikovány. Upraveno dle [16]...... | 27 |
| Obrázek 12 Ukázka použitých obrazových záznamů. Zleva snímek MRI-chrupavky, snímek CT-jater a MRI-cévy. Zdroj vlastní | 29 |
| Obrázek 13 Vývojový diagram aplikace šumu. Zdroj vlastní | 30 |
| Obrázek 14 Srovnání Gaussova šumu u snímků chrupavky a cévního řečiště zleva nativní snímky, dále parametry $\sigma^2 = 0,1$ $\mu = 0,05$ a $\sigma^2 = 0,5$ $\mu = 0,05$. Zdroj vlastní..... | 31 |
| Obrázek 15 Srovnání Salt and Pepper šumu na snímcích chrupavky a cévního řečiště zleva nativní snímky, dále parametry $d = 0,1$ a $d = 0,3$. Zdroj vlastní | 31 |
| Obrázek 16 Srovnání Speckle šumu na snímcích chrupavky a cévního řečiště zleva nativní snímky, dále parametry $\sigma^2 = 0,1$ a $\sigma^2 = 0,3$. Zdroj vlastní..... | 32 |
| Obrázek 17 Princip mediánového filtru..... | 33 |

| | |
|--|----|
| Obrázek 18 Srovnání použití mediánového filtru na Salt and Pepper šumu na snímcích chrupavky a cévního řečiště zleva nativní snímky, dále parametry $d=0,3$ a výsledek filtrace. Zdroj vlastní..... | 33 |
| Obrázek 19 Vývojový diagram Otsu prahování Zdroj vlastní | 34 |
| Obrázek 20 Srovnání použití Otsu metody na snímky MRI cév a MRI chrupavky. Zleva nativní snímky, 3 segmentované oblasti a 5 segmentovaných oblastí. Zdroj vlastní..... | 35 |
| Obrázek 21 Vývojový diagram shlukování K-means. Zdroj vlastní..... | 35 |
| Obrázek 22 Srovnání použití shlukování K-means na snímky MRI cév a MRI chrupavky. Zleva nativní snímky, 3 shluky a 5 shluků. Zdroj vlastní | 36 |
| Obrázek 23 Ukázka použití shlukování K-means do třech oblastí na snímek CT cév. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Gaussovým šumem. Zdroj vlastní | 38 |
| Obrázek 24 Ukázka použití prahování Otsu do třech oblastí na snímek CT cév. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Gaussovým šumem. Zdroj vlastní | 38 |
| Obrázek 25 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody K-means. Snímky CT-cévy. Typ šumu Salt and Pepper. Zdroj vlastní..... | 39 |
| Obrázek 26 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody Otsu. Snímky CT-cévy. Typ šumu Speckle. Zdroj vlastní..... | 39 |
| Obrázek 27 Srovnání mediánu evaluačních parametrů metod Otsu a K-means. Typ šumu Salt and Pepper. Snímky CT-cévy. Při segmentaci do 3 segmentačních tříd. Zdroj vlastní..... | 40 |
| Obrázek 28 Srovnání mediánu evaluačních parametrů mezi segmentací s použitím filtru a bez. Typ šumu Gauss. Snímky CT-cévy. Při segmentaci do 10 segmentačních tříd. Zdroj vlastní..... | 40 |
| Obrázek 29 Ukázka použití shlukování K-means do třech oblastí na snímek MRI cév. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Speckle šumem. Zdroj vlastní | 41 |
| Obrázek 30 Ukázka použití prahování Otsu do třech oblastí na snímek MRI cév. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Speckle šumem. Zdroj vlastní | 41 |
| Obrázek 31 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody K-means. Snímky MRI-cévy. Typ šumu Salt and Pepper. Zdroj vlastní..... | 42 |
| Obrázek 32 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody Otsu. Snímky MRI-cévy. Typ šumu Salt and Pepper. Zdroj vlastní | 42 |

| | |
|--|----|
| Obrázek 33 Srovnání mediánu evaluačních parametrů metod Otsu a K-means. Snímky MRI-cévy. Typ šumu Salt and Pepper. Při segmentaci do 3 segmentačních tříd. Zdroj vlastní | 43 |
| Obrázek 34 Srovnání mediánu evaluačních parametrů mezi segmentací s použitím filtru a bez. Typ šumu Gauss. Snímky MRI-cévy. Při segmentaci do 10 segmentačních tříd. Zdroj vlastní | 43 |
| Obrázek 35 Ukázka použití shlukování K-means do třech oblastí na snímek CT-játra. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Salt and Pepper šumem. Zdroj vlastní | 44 |
| Obrázek 36 Ukázka použití prahování Otsu do třech oblastí na snímek CT-játra. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Salt and Pepper šumem. Zdroj vlastní | 44 |
| Obrázek 37 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody K-means. Snímky CT-játra. Typ šumu Salt and Pepper. Zdroj vlastní | 45 |
| Obrázek 38 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody Otsu. Snímky CT-játra. Typ šumu Salt and Pepper. Zdroj vlastní | 45 |
| Obrázek 39 Srovnání mediánu evaluačních parametrů metod Otsu a K-means. Typ šumu Salt and Pepper. Snímky CT-játra. Při segmentaci do 10 segmentačních tříd. Zdroj vlastní | 46 |
| Obrázek 40 Srovnání mediánu evaluačních parametrů mezi segmentací s použitím filtru a bez. Typ šumu Gauss. Snímky CT-játra. Při segmentaci do 3 segmentačních tříd. Zdroj vlastní | 46 |
| Obrázek 41 Ukázka použití shlukování K-means do třech oblastí na snímek MRI-chrupavky. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Speckle šumem. Zdroj vlastní | 47 |
| Obrázek 42 Ukázka použití prahování Otsu do třech oblastí na snímek CT-játra. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Speckle šumem. Zdroj vlastní | 47 |
| Obrázek 43 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody K-means. Snímky MRI-chrupavky. Typ šumu Gauss. Zdroj vlastní | 48 |
| Obrázek 44 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody Otsu. Snímky MRI-chrupavky. Typ šumu Gauss. Zdroj vlastní | 48 |
| Obrázek 45 Srovnání mediánu evaluačních parametrů metod Otsu a K-means. Typ šumu Speckle. Snímky MRI-chrupavky. Při segmentaci do 3 segmentačních tříd. Zdroj vlastní | 49 |
| Obrázek 46 Srovnání mediánu evaluačních parametrů mezi segmentací s použitím filtru a bez. Typ šumu Speckle. Snímky MRI-chrupavky. Při segmentaci do 5 segmentačních tříd. Zdroj vlastní | 49 |

Seznam tabulek

Tabulka 1 Seznam použitých obrazových dat. Zdroj vlastní..... 29

Tabulka 2 Rozsah parametrů šumu. Zdroj vlastní 30

Úvod

Vizuální obrazová informace hraje důležitou roli téměř ve všech oblastech našeho života. V dnešní době je většina těchto informací reprezentována v digitální formě obrazu. Toto zobrazování je všude přítomné od televizního obrazu přes digitální fotografie až po snímky CT. Tato práce se bude zabývat předzpracováním a následnou segmentací medicínských obrazů.

Předzpracování a následná segmentace obrazů jsou operace, které mají široké spektrum využití v oblasti diagnostiky medicínských obrazových dat, a to zejména z důvodů snadnějšího sledování zájmových oblastí nebo jednodušší lokalizace neznámých objektů. Tímto zpracováním se nejen zlepší viditelnost sledovaných oblastí, ale také může nastat objevení objektů nových.

Pojmem předzpracování je myšleno upravení obrazu pro lepší analýzu, identifikaci nebo jen pro lepší pozorování obrazu člověkem. To znamená, upravit obraz tak, aby byl potlačen šum, odstraněno zkreslení a aby se potlačili či zvýraznili rysy v obraze. Kvalita předzpracování má velký vliv na výslednou segmentaci. Jednou z technik předzpracování obrazu je korekce zkreslení. Dále se využívají transformace např. geometrická a jasová. Další metodiky používané pro předzpracování jsou filtrace obrazu nebo ošetření.

Díky rostoucímu vývoji počítačové techniky přichází možnost využití plné nebo částečné automatizované segmentace. Kvalitní segmentace je důležitým krokem ve zpracování medicínských dat. Jedním z hlavních úkolů segmentace v medicíně je například rozeznání patologické tkáně od zdravé. Segmentace pracuje na principu separování objektů od nezajímavého pozadí. Tato práce bude zaměřená na segmentační metody s regionovou orientací.

Cílem této práce bude výběr jednotlivých metod předzpracování a segmentace, které se dále budou aplikovat na vybraná obrazová data. Dosažené výsledky se použijí na zhodnocení výkonosti jednotlivých metod. Z výsledné analýzy předzpracování a segmentace se také získají důležité informace o vlastnostech testovaných metod. Práce bude zakončena návrhem vlastní laboratorní úlohy, ve které budou využity poznatky získané v této práci.

1 Základní principy zpracování medicínských obrazových dat

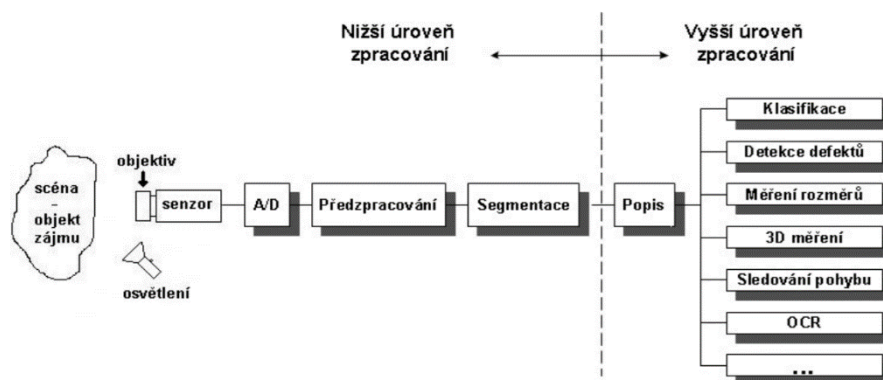
1.1 Definice obrazu

Obraz může být definován jako dvourozměrná funkce, $f(x, y)$, kde x a y jsou prostorové (rovinné) souřadnice a amplituda f na libovolném páru souřadnic $f(x, y)$, se v tomto bodě nazývá intenzita nebo úroveň šedé. Když souřadnice x , y a hodnota intenzity f jsou konečné neboli diskrétní veličiny, obraz nazýváme digitální. Oblast digitálního zpracování obrazu se zabývá zpracováním číselných obrazů pomocí digitální techniky. Digitální obraz se skládá z konečného počtu prvků, z nichž každý má určité umístění a hodnotu. Všechny body jsou umístěny v matici o $M \times N$ bodech. Tyto prvky se nazývají pixely. Funkce tří proměnných se používá buď při plošném měnění obrazu v čase $f(x, y, t)$ nebo u objemových obrazů např. tomografie [7].

1.2 Postup zpracování

Postup zpracování obrazu můžeme rozdělit do čtyř základních kroků [2]:

- První základní krok je napodobení skutečného tělesa pomocí digitálního obrazového signálu. Tento krok zahrnuje snímání obrazových dat např. pomocí kamery, tomografu nebo termovize. Tento krok obsahuje i operace předzpracování např. filtrace šumu, geometrické nebo radiometrické korekce. Tyto operace nám slouží k vylepšení obrazu před dalším zpracováním.
- V druhém kroku se provádí hledání objektů. Obraz je složen z částí, které pravděpodobně patří k jednotlivým objektům, např. analýza mnohostěnu vyústí v hranové segmenty anebo ve dvojrozměrné stěny těles. Při hledání objektů je důležitá informace o konkrétním aplikačním oboru. Díky této znalosti se dá obejít šum a potíže s chybnými obrazovými daty.
- V třetím kroku se zabýváme geometrickou reprezentací, jejím výsledkem je zachycení dvojrozměrných a trojrozměrných tvarů. Neboli provádíme hledání objektů např. u mnohostěnu by to byla identifikace stěn.
- Ve čtvrtém kroku posuzujeme kvalitativní a kvantitativní vlastnosti objektů a jejich automatické posuzování poznatků pomocí relačních modelů.




Obrázek 1 Schéma postupu pro zpracování obrazu [22].

1.3 Snímání obrazu

Prvotním krokem je transformace vstupní optické veličiny na analogový elektrický signál spojený v čase. Signál vzniká měřením množství světelné energie dopadajícího na obrazové pixely. V medicíně používáme snímání obrazu u diagnostických metod jako jsou RTG, CT nebo MRI. Hodnoty obrazové funkce vždy odpovídají nějaké fyzikální veličině, a to buď jasu u obrazu TV kamery, teplotě u termovizní kamery nebo schopnosti pohlcovat záření v daném bodě u tomografu. Na výsledek snímání má vliv spousta různých faktorů. Vstupní signál nemusí být zpravidla pořízen vždy jen snímáním jasu kamerou nebo skenerem. Může být snímáno např. elektromagnetické záření, gama záření, energie akustických vln, tepelné záření nebo rentgenové záření [5].

1.4 Digitalizace

Následujícím krokem zpracování obrazu je převedení analogového signálu na signál digitální. Digitalizace vzniká vzorkováním obrazu do matice $M \times N$ bodů a kvantováním spojitě jasové úrovně. Čím jemnější je vzorkování a kvantování, tím lépe napodobíme původní spojitý signál. Díky kvantování nabývá jasová funkce celočíselné hodnoty. Vzorkování se řídí Shannonovou větou, která říká, že vzorkovací frekvence musí být alespoň dvakrát větší než nejvyšší frekvence vzorkovaného signálu. Důležitým krokem digitalizace je správné zvolení vhodného rozlišení obrazu. Malé rozlišení postrádá kvalitu obrazu a velké rozlišení má zase vysoké nároky na paměť. Rozlišení se udává v DPI (dots per inch). U kvantování je důležité volit počet úrovní tak, aby nedocházelo k falešným obrysům. Počet úrovní má dostatečně velký vliv na vykreslení jemných detailů obrazu. Pro lidské oko by jich mělo být více než 50. Jedna z dalších důležitých součástí je volba vzorkovací mřížky. V praxi je nejčastěji používána čtvercová mřížka, která má ale problém se spojitostí oblastí. Výhodou čtvercové mřížky je snadná implementace, u hexagonální mřížky zase snadněji určujeme vzdálenosti, ale nemůžeme použít Fourierovu transformaci [2] [8].



Obrázek 2 Čtvercová a hexagonální vzorkovací mřížka Upraveno dle [5].

1.5 Předzpracování obrazu

V momentě, kdy jsme dostali převedený digitální signál, nám nastává fáze předzpracování. Obraz má určité nedostatky z důvodu špatných podmínek snímání nebo špatně zvoleného vybavení. Předzpracování má také za úkol odstranit nedostatky vzniklé při digitalizaci, např. šum nebo zkreslení. Jednou z technik předzpracování obrazu je korekce zkreslení. Dále se využívá transformace, např. geometrická a jasová. Transformace je změna hodnot obrazové funkce $F(x, y)$. Další metodiky používané pro předzpracování jsou filtrace obrazu nebo ošetření obrazu. Toto je pouze okrajový výčet metod, existuje celá řada dalších technik. Níže uvedené metody budou v práci více rozvedeny [2] [6].


- Jasová transformace
- Geometrická transformace
- Filtrace a ošetření

1.6 Segmentace

Mezi nejpoužívanější diagnostické metody v medicíně patří počítačová tomografie, magnetická rezonance, ultrazvuk a digitální mamografie. S rostoucím vývojem počítačové techniky přichází možnost využití plné nebo částečné automatizované segmentace. Kvalitní segmentace je důležitým krokem ve zpracování medicínských dat. Jedním z hlavních úkolů segmentace v medicíně je například rozeznání patologické tkáně od zdravé. Segmentace pracuje na principu separování objektů od nezajímavého pozadí.

Hlavním cílem segmentace je extrakce objektů. Segmentace bývá nejčastěji založena na principu detekci hran nebo na detekci celých oblastí. Dokonalá segmentace složitých obrazců není v prvotní fázi splnitelná. Okamžitým přínosem je redukce dat [1] [9].

Mezi časté problémy segmentace patří data, které mohou být poškozená šumem nebo osvětlením. Objekty mohou být těžko rozdělitelné podle hranic, jelikož se mohou překrývat. Hranice tkání nemusí být dobře viditelné vlivem šumu nebo artefaktů. Složitá anatomická struktura nemusí být dobře separovaná [9].



Obrázek 3 a)MRA snímek segmentace tepen b) segmentace cévního systému
c)segmentované tepny Upraveno dle [9].

Definice segmentace říká, že konkrétní segmentovaný obraz je konečná množina oblastí $\{R_1, R_2, \dots, R_s\}$, které jsou vzájemně disjunktí [3]

$$R_i \cap R_j = \emptyset, i \neq j \quad (2.1)$$

a pokrývající oblast úplně:

$$R = \bigcup_{i=1}^S R_i \quad (2.2)$$

Segmentaci můžeme mít kompletní, pokud objekty korespondují se vstupním obrazem, nebo částečnou, kdy objekty po segmentaci nepřímo souhlasí s objekty ve vstupním obrazu. Pro segmentaci můžeme využívat (2D) obrazové algoritmy nebo (3D) objemové algoritmy. Segmentaci můžeme rozdělit na tři nejzákladnější metody [1] [9]:

- Metody využívající globální znalosti
- Metody vycházející z určování hranic (hranová reprezentace)
- Metody regionově orientované (vytvářející oblasti)

U metod využívajících globální znalosti provádíme extrakci na základě znalosti (jasu, textury, rychlostního pole apod.). Při určování hranic probíhá analýza na základě rozdílu hodnot obrazových pixelů. Regionově orientované metody jsou principálně stejné jako metody založené na detekci hran, ale hranice naleznou metodou založenou na detekci hran nemusí být vždy stejné jako hranice nalezené regionově orientovanými metodami. Jelikož kontury regionu mohou být porušené a hrany nemusí ohraničovat celý region. Jako další metody můžeme považovat metody statické, do kterých patří prahování a shluková analýza, nebo metody hybridní, u kterých se využívá postup složený z více metod. Existuje celá řada metod, které nejdou vždy zařadit do předchozích kategorií. Samostatnou kategorií pak tvoří Neuronové sítě [1] [9].

1.7 Klasifikace

Posledním krokem zpracování obrazu je klasifikace. V podstatě to znamená zařazení nalezených objektů do předem stanovených tříd. Klasifikaci dělíme na dvě metody, příznakové rozpoznávání a strukturální rozpoznávání. Příznaková metoda je založena na příznacích, což je skupina číselných charakteristik objektů. Strukturální metoda využívá kvalitativních parametrů objektu [5] [17].

1.7.1 Příznakové rozpoznávání

Každému obrazu odpovídá bod v N-dimenzionálním příznakovém prostoru. Pokud budou body ležet blízko sebe, je to předpoklad k tomu, že budou patřit do stejné třídy. Princip příznakové klasifikace spočívá v rozdělení prostoru na tolik částí, kolik je tříd [17].

1.7.2 Strukturální rozpoznávání

Obraz je popsán podle základních popisných elementů (primitiv) a vztahů mezi nimi. Pomocí těchto vlastností a vztahů můžeme určit jejich strukturální vlastnosti. Využívá se analogie mezi strukturou obrazu a syntaxí, resp. gramatikou jazyka. Obrazy se skládají z jednoduchých částí podobně jako věty se skládají ze slov, slova ze slabik atd. Výhodou při použití strukturální klasifikace je, že nám umožňuje získání popisu struktury obrazu, jeho částí a vztahů mezi nimi [17].

Obě metody mají své výhody i nevýhody a spíše se vzájemně doplňují. Proto se v praxi využívá obou metod, strukturálních pro získání struktur popisu celku a příznakových pro rozpoznání jednotlivých primitiv [17].

2 Základní procedury předzpracování obrazových dat

Podklady pro tvorbu této kapitoly byly čerpány z [2], [6], [14]. Pojmem předzpracování obrazu je myšleno upravení obrazu pro lepší analýzu obrazu, identifikaci objektů nebo jen pro lepší pozorování obrazu člověkem. To znamená upravit obraz tak, aby byl potlačen šum, odstraněno zkreslení, a aby se potlačili či zvýraznili rysy v obraze. Kvalita předzpracování má velký vliv na výslednou segmentaci.

Základní metody předzpracování obrazu:

- Jasová transformace
- Geometrická transformace
- Filtrace a ošetření

2.1 Jasová transformace

Jasová transformace nám mění vstupní hodnotu jasu na výstupní hodnotu. Transformaci hodnot jasu můžeme rozdělit na globální, lokální a bodovou. Globální jasová transformace je využita při transformaci jasové stupnice. Hodnota jasu je transformována na jinou hodnotu jasu bez ohledu na polohu v obraze. V lokální jasové transformaci je nová hodnota jasu vypočítána z lokálního prostředí pixelu. Bodová transformace je využita u jasových korekcí, jelikož jas v bodě výstupního obrazu závisí

na hodnotě jasu v bodě ve vstupním obraze. Jasová transformace je důležitá právě tehdy, kdy potřebujeme zkoumanou část obrazu zvýraznit oproti okolí. Tyto úpravy mohou také zlepšit a zjednodušit diagnostiku a zvýraznit důležité detaily.

2.1.1 Transformace jasové stupnice

Metoda transformace jasové stupnice nezávisí na hodnotě jasu u jednotlivých pixelů, ale na hodnotě jasu celého obrazu. Z praktického hlediska je transformace jasové stupnice vhodná pro úpravy obrazu, které vytvářejí jednodušší interpretaci obrazu. Příkladem může být snaha o zvýšení kontrastu původně nekонтastního rentgenového obrazu. Snímací zařízení mají většinou velký dynamický rozsah naměřených hodnot (rozdíl mezi minimem a maximem jednotlivých bodů). Jasové hodnoty bodů převážně využívají jen malou část tohoto rozsahu. Důsledkem toho je, že data mají malý kontrast.

Transformace je dána vztahem:

$$q = T(p) \quad (3.1)$$


q = nová stupnice jasu

p = původní stupnice jasu

T = transformační funkce

Transformace jasové stupnice je zejména důležitá pro úpravy, při kterých potřebujeme snadnou interpretaci obrazu. Příkladem může být zvýšení kontrastu u rentgenového snímku. U automatických analýz obrazu nemá metoda transformace jasové stupnice žádný význam může spíše uškodit, a to ztrátou obrazových informací.


Ideální zvýšení kontrastu monochromatického obrazu je vytvořeno ekvalizací (vyrovnáním) histogramu. Optimální by byl histogram se stejnými četnostmi. Ekvalizací zvýšíme kontrast na úrovních blízkých maximu a snížíme kontrast v blízkosti minima.



Obrázek 4 Zvýšení kontrastu po ekvalizaci histogramu. [24]

2.1.2 Jasová korekce

U jasové korekce je využita bodová transformace hodnot. Někdy může záviset i na jasu obrazových bodů v malém definovaném okolí daného bodu. Při snímání má mít v ideálních případech každý bod stejnou citlivost bez ohledu na polohu v obraze. Ve špatně zvolených podmínkách může vznikat odchylka, např. při špatně zvoleném osvětlení nebo při špatné citlivosti optické soustavy. Jsou-li poruchy systematické můžeme je potlačit korekcí, a to na základě znalosti odchylky.



Obrázek 5 Schéma jasové korekce. [23]

Porušení obrazu aproximujeme modelem poruchy $e(x, y)$. Zkreslený obraz $f(x, y)$ je dán vztahem:

$$f(x, y) = e(x, y) \cdot g(x, y) \quad (3.2)$$

Model poruchy lze stanovit buď analyticky nebo fyzicky. Analytický model funguje na principu aproximace poruchy analytickou plochou. Empirický model představuje pořízení etanolového snímku. Korekce zkreslení je možná, pokud je možné zkreslení charakterizovat. Vhodné použití těchto korekcí může nápomoci zvýraznění a snazší interpretaci jednotlivých objektů v obraze.

2.2 Geometrická transformace

Pomocí geometrické transformace vypočteme ze souřadnic vstupního obrazu souřadnice výstupního obrazu. Při transformaci provádíme operace jako zvětšení, otočení nebo složitější zobrazování. Dále transformace dovolují odstranit geometrické zkreslení vzniklé při pořizování obrazu, např. korekce geometrických vad.

U transformace plošného obrazu je použita vektorová funkce T , která zobrazí bod x, y do bodu x', y' .

$$X' = T_x(x, y) \quad (3.3)$$

$$Y' = T_y(x, y) \quad (3.4)$$

Rovnice jsou buď známy předem, nebo je možné hledat vztah na základě původního a transformovaného obrazu. Geometrická transformace se skládá ze dvou kroků.

2.2.1 Transformace souřadnic bodů

Transformace souřadnic bodů přidělí k bodu výstupního obrazu odpovídající souřadnici. Poloha výstupního bodu nemusí odpovídat mřížce vstupního obrazového signálu. Transformační vztah souřadnic se aproximuje polynomiální funkcí m -tého stupně. Vztah vyjádříme v tomto tvaru.

$$x' = \sum_{r=0}^m \sum_{k=0}^{m-r} a_{rk} x^r y^k \quad (3.5)$$

$$y' = \sum_{r=0}^m \sum_{k=0}^{m-r} b_{rk} x^r y^k \quad (3.6)$$

Tato transformace je lineární ke koeficientům a_{rk} a b_{rk} . Výhodou je, že metodou nejmenších čtverců určíme koeficienty a_{rk} a b_{rk} na základě předem zvolené množiny dvojic sobě odpovídajících bodů ve vstupním a výstupním obraze. V momentě, kdy se žádná geometrická transformace v závislosti na pozici v obraze příliš nemění, nám stačí v rovnici aproximační polynomy nízkého stupně $m = 2$, $m = 3$.

V praxi se obvykle nahrazuje bilineární transformací. K jejímu vytvoření nám postačí 4 dvojice sobě odpovídajících bodů.

$$x' = a_0 + a_1x + a_2y + a_3xy \quad (3.7)$$

$$y' = b_0 + b_1x + b_2y + b_3xy \quad (3.8)$$

Neobvyklým případem bilineární transformace je afinní transformace. Při této transformaci proběhne rotace, translace a zkosení.

$$x' = a_0 + a_1x + a_2y \quad (3.9)$$

$$y' = b_0 + b_1x + b_2y \quad (3.10)$$

Ke každému bodu v rovině náleží sloupcový vektor $[x; y]^T$. Proto jde afinní transformace vyjádřit pomocí maticových operací. Zavedení formalismu homogenních souřadnic nám umožní v geometrických transformacích vyjádřit posun, rotaci i afinní transformaci jako součin s jednou maticí. Důležitou myšlenkou je reprezentovat bod ve vektorovém prostoru o jednu dimenzi větším. Pro vyjádření plošného obrazu $[x; y]^T$ ve 3D vektorovém prostoru se používá tvar jako $[\lambda x; \lambda y; \lambda]^T$, kde $\lambda = 0$. Pro jednoduchost se obvykle používá jedno z nekonečně mnoha vyjádření bodu v homogenních souřadnicích, a to $[x; y; 1]^T$. Po zavedení homogenních souřadnic se afinní zobrazení vyjádří maticově takto:

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} a_1 & a_2 & a_0 \\ b_1 & b_2 & b_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (3.11)$$

Můžeme provádět i náročnější operace jako je např. zkreslení. Tuto operaci provádíme tak, že obraz rozdělíme na menší pod obrazy. U všech pod obrazů se použije geometrická transformace, odhadnutá z dvojice sobě odpovídajících si bodů. Zkreslení, které se nám vytvoří uvnitř každého pod obrazu, je upraveno zvlášť.

2.2.2 Aproximace jasové funkce

K neceločíselné hodnotě výstupního bodu x' , y' přiřazuje celočíselnou hodnotu v celočíselné pozici.

Druhým krokem geometrické transformace je hledání hodnot jasu každého transformovaného bodu. Po transformaci souřadnic bodů můžeme dostat jako výstupní hodnotu neceločíselné souřadnice bodů, jelikož výstupní obraz nemusí odpovídat mřížce vstupního obrazu.

Z důvodu toho, že máme dostupné vzorky obrazové funkce v rastru vstupního obrazu, je na místě aproximace (nebo též interpolace) průběhu plochy výstupního obrazu z dostupných vzorků vstupního obrazu. Obvykle se dostupné vzorky proloží polynomem. Díky toho získáme analytickou rovnici a po dosazení dostaneme hodnoty v bodech předepsaného rastru. Přesnost aproximace ovlivňuje kvalitu výstupního obrazu.

Jas aproximován ze vstupního obrazu odpovídá jasu bodu ve výstupní mřížce. Výsledkem je jas $f_n(x, y)$. Index n určuje jednotlivé interpolační metody. Jas můžeme vyjádřit jako dvojrozměrnou konvoluci:

$$f_n(x, y) = \sum_{l=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} g_s(l\Delta x, k\Delta y) h_n(x - l\Delta x, y - k\Delta y) \quad (3.12)$$

Funkci h_n se říká interpolační jádro. Většinou se využívá interpolační jádro, které pokrývá menší okolí zpracovaného bodu. Z důvodu menší výpočetní náročnosti. Vně okolí je $h_n = 0$.

Pro interpolaci se využívá několik aproximačních polynomů, dále uvedeme tři z nich.

2.2.3 Metoda nejbližšího souseda

Metoda nejbližšího souseda funguje na principu přiřazení bodu (x, y) hodnotu jasu nejbližšího bodu g v diskretní mřížce. Interpolace této metody je dána vztahem:

$$f_1(x, y) = g_s(\text{round}(x), \text{round}(y)) \quad (3.13)$$

Maximální chyba metody nejbližšího souseda je nejvýše půl pixelu.

2.2.4 Lineární interpolace

Pomocí okolních čtyř bodů sousedních s (x, y) můžeme předpokládat, že obrazová funkce je lineární kombinací těchto bodů. Vliv každého bodu je úměrný blízkosti zpracovaného bodu. Lineární interpolace je dána vztahem:

$$f_2(x, y) = (1 - a)(1 - b)g_s(l, k) + a(1 - b)g_s(l + 1, k) + b(1 - a)g_s(l, k + 1) + abg_s(l + 1, k + 1) \quad (3.14)$$

$$\text{kde} \quad l = \text{round}(x), \quad a = x - l$$

$$k = \text{round}(y), \quad b = y - k$$

2.2.5 Bikubická interpolace

Metoda bikubické interpolace zpřesňuje model obrazové funkce pomocí lokální interpolace bikubickým polynomem, využívá se okolí o 16 bodech. Tato metoda mnohem lépe zachovává detaily. Bikubická interpolace umožňuje zoom v libovolné oblasti.

2.3 Filtrace a ošetření

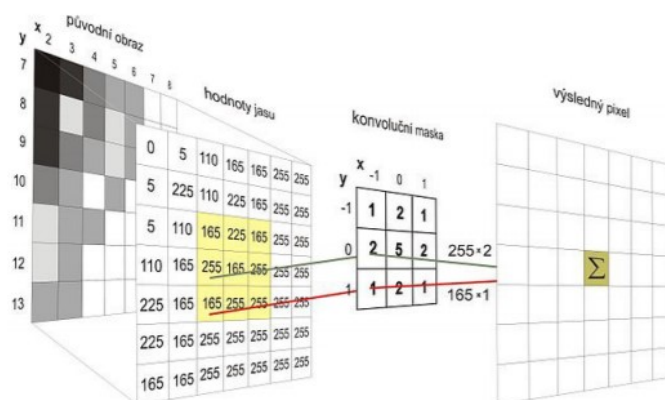
Do obrazu se při snímání a digitalizaci dostává šum. Vznikají pixely, které se liší od svého okolí. Potlačení šumu je důležitým krokem před provedením segmentace. Vyhlašováním můžeme tento jev potlačit pomocí znalosti hodnot jasu v obraze, nebo při možnosti využití více snímků stejného obrazu. Pomocí aritmetického průměru můžeme získat hledanou hodnotu zkresleného pixelu. Ale touto operací dochází k nechtěnému jevu rozmazání hran. Proto využíváme operaci ostření, která zvýrazní hrany, ale zase i šum. Tyto dvě operace jsou si protikladné.

2.3.1 Diskrétní konvoluce

Konvoluce je matematická operace, kdy použijeme funkci zpracovaného obrazu a jádro (konvoluční masku). Konvoluci matematicky vyjádříme jako:

$$f(x, y) \cdot h(x, y) = \sum_{i=-k}^k \sum_{j=-k}^k f(x-i, y-j) \cdot h(i, j) \quad (3.15)$$

Jádro (konvoluční maska) je filtr, který chceme na obraz použít. Masku je vhodné zapisovat formou matice, pomocí které provádíme násobení hodnot a následný součet. Výsledná hodnota je uložena jako nový bod. Pomocí konvoluce můžeme definovat různé obrazové filtry jako dolní propust (na vyhlazování) nebo horní propust (na doostřování). Využívá se tam, kde pro určení nového bodu uvažujeme okolí daného bodu.



Obrázek 6 Princip konvoluce Upraveno dle [6].

Základní typy masek:

Gaussův filtr:

$$\begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix}$$

Zvýraznění hran:

$$\begin{pmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{pmatrix}$$

Laplaceův operátor:

$$\begin{pmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{pmatrix}$$

Sobelův operátor (svislé hrany):

$$\begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix}$$

2.3.2 Vyhlazování průměrováním

Pomocí konvoluce přiřadíme každému bodu novou zprůměrovanou hodnotu jasu. Při použití větších masek dojde k lepšímu vyhlazení, ale také dojde ke ztrátě detailů. Zde je příklad konvoluční masky:


$$h = \frac{1}{9} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$

Při použití matice s vyšší střední hodnotou můžeme omezit rozmazání hran. Tato matice se značí jako váhová. Volba masky je závislá na povaze sledovaného objektu.

2.3.3 Mediánová filtrace

Mediánová filtrace je nelineární metoda, která má dobré výsledky při potlačení černých a bílých bodů v obraze. Medián je prostřední prvek v uspořádané posloupnosti hodnot. Principem je posouvání okna masky po obraze a výběru mediánu z hodnot, které leží pod touto maskou. Metoda redukuje stupeň rozmazání hran a dobře potlačuje impulsní šum. Nevýhodou je, že porušuje tenké čáry a ostré rohy v obraze.

3 Komplexní rešerše regionální segmentace s orientací na identifikaci zájmových oblastí



Obrázek 7 a) nativní snímek, b) snímek s vyšším nastaveným prahem, c) snímek s nižším nastaveným prahem, d) snímek s optimálně zvoleným prahem. Upraveno dle [18]

Metody regionální segmentace vychází z homogenity oblastí, tyto oblasti musí být definovány určitými parametry jako jsou barva, tvar, úroveň šedé nebo textura. Často se využívají tam kde je obraz porušen šumem, jelikož jsou v těchto situacích regionální segmentace lepším řešením. Metody jsou založeny na klasifikaci 2D pixelů či 3D voxelů. [3]

3.1 Prahování (Thresholding)

Nejednodušší metodou je prahování. Obraz se rozdělí podle předem definovaných prahu do skupin pixelů, které mají hodnoty v rozsahu a které mají hodnoty mimo rozsah předem zvoleného prahu. Obraz se podle předem zvoleného prahu rozdělí na pozadí a hledaný objekt [10] [11].

Definice prahování:


$$f(x, y) = \begin{cases} 1 & g(x, y) \geq T \\ 0 & g(x, y) < T \end{cases} \quad (4.1)$$

Existuje několik algoritmů prahování, které můžeme rozdělit na globální, místní a adaptivní. Globální technika funguje na principu předem zvolené jedné globální hodnoty z histogramu obrazu. Místní prahová technika závisí na vlastnostech místního obrazu, např. průměrné hodnotě šedé. Pokud jsou prahové hodnoty vybrány nezávisle pro každý pixel nebo skupinu pixelů, pak se prahová hodnota nazývá dynamická nebo adaptivní. Existuje i modifikace metody prahování, která se nazývá Otsu metoda prahování. Metoda Otsu pracuje na základě statistického parametru rozptylu [10].

Definice adaptivního prahování:

$$f(x, y) = \begin{cases} 1 & g(x, y) \in A_1, \\ 2 & g(x, y) \in A_2, \\ \dots & \\ n & g(x, y) \in A_n, \\ 0 & \text{jinak,} \end{cases} \quad (4.2)$$

Prahování je vhodnější pro jednodušší obrazy. Výpočet globální hodnoty je méně náročný než výpočet místní hodnoty. Metoda je užitečná pro segmentaci struktur z pozadí a pro extrakci oblastí, které jsou velmi malé. Nevýhodou je, že metoda prahování nezaručuje správné rozdělení pixelů, jelikož proces zohledňuje pouze intenzitu pixelů. Tyto algoritmy se zřídka používají samostatně. Často jsou využívány jako kvalitní před segmentační krok [12].



Obrázek 8 Adaptivní prahování. A) původní obrázek. B) globální prahování. C) rozdělení na pod obrazy. D) segmentace jednotlivých pod obrazů. Upraveno dle [1].

3.2 Narůstání oblastí (Region – growing)

Principem metody narůstání oblastí je zvolení menších bodů (semen) charakterizujících danou oblast. Jednotlivé body mají určitý rozsah, podle kterého se k němu přidělují ostatní body a tím vzniká narůstání. U této metody je potřeba kontroly homogenity každého regionu, aby došlo k přesné segmentaci. Narůstání probíhá do momentu, než projdou všechny body testem podobnosti s referenčním bodem. Takhle porovnáme předem zvolený bod s celým obrazem. Body se porovnávají nejčastěji podle intenzity, lokálního průměru, či odchylky. Odstraňováním slabých hran dochází ke spojení větších oblastí, jsou-li splněny požadavky. Výsledek je závislý na pořadí spojování i na síle společné hranice, která může ovlivňovat spojení [9] [11].

Postup metody [1]:

Segmentaci můžeme chápat tak že oblast R se rozdělí na podoblasti R_1, R_2, \dots, R_n


1) $\bigcup_{i=1}^n R_i = R$ (Každý pixel náleží nějaké oblasti)

2) R_i je souvislá oblast, $i = 1, 2, \dots, n$

3) $R_i \cap R_j = \emptyset$, pro $i \neq j$ (Body jednotlivých oblastí se nebudou prolínat)

4) $P(R_i) = TRUE$, pro $i = 1, 2, \dots, n$ (Splnění vlastností pro každou oblast)

5) $P(R_i \cup R_j) = FALSE$, pro $i \neq j$ (Oblasti R_i a R_j jsou nesouvislé)



Obrázek 9 a) poloha výchozích bodů b) narůstání oblastí c) výsledek segmentace. Upraveno dle [10].


Výhodou metody narůstání oblastí je jednoduchý koncept, avšak pravidla pro seskupení jsou v praxi poněkud složitější. Pro úspěšnou segmentaci stačí malý počet bodů. Další výhodou je dobré oddělování regionů. Nevýhodou je velká náročnost výpočtu a těžká volba správného výchozího bodu. Metoda je citlivá na obrazové artefakty a šum. Podobně jako prahování se nevyužívá samostatně, ale jako kombinace k jiným metodám. [10] [11]

3.3 Dělení a spojování (Split and merge)

Metoda dělením a spojováním je opakem metody narůstání oblastí. Začínáme jednou velkou oblastí, která představuje celý obraz. Pokud oblast nesplňuje podmínky homogenity, provádí se dělení oblasti na čtyři kvadranty. Oblasti, které splňují podmínky homogenity, se spojí. Proces přetrvává do doby, než nejde provést rozdělení nebo sloučení. Měřenou veličinou pro určení podmínky homogenity může být, rozptyl nebo rozdíl mezi maximálním a minimálním pixelem v oblasti. [7].

Postup metody [1]:

- $P(R_i) = FALSE$, pokud není splněna podmínka probíhá dělení oblastí
- $P(R_j \cup R_k) = TRUE$, při splnění podmínky je provedeno spojení
- Proces opakujeme, pokud další rozdělení nebo spojení oblastí není možné



Obrázek 10 Schéma metody dělením a slučováním Upraveno dle [1].

3.4 Shluková analýza

Hlavním úkolem shlukové analýzy je v množině objektů identifikovat její podmnožiny. To znamená přiřadit vektor, který bude reprezentovat nějaký pixel určité oblasti (shluku). Hodnoty vektoru nesou nějakou informaci, např. hodnotu jasu nebo barvy. Členové každého shluku si musí být navzájem podobní, ale nesmí si být podobní s členy mimo shluk. Jestliže máme nějakou množinu X , která je tvořena z disjunktních, neprázdných podmnožin, platí $i \neq j$ [13].

$$C_i \cap C_j \neq \emptyset, \quad C_1 \cup C_2 \cup \dots \cup C_n = X \quad (4.3)$$

Shlukování znamená rozkládání množiny X na komponenty C_i . Komponenty této množiny se nazývají shluky.

Metody shlukové analýzy můžeme rozdělit na hierarchické a nehierarchické. Hierarchické fungují na principu neprázdných podmnožin množiny X , v které jsou průnikem každých dvou podmnožin, buď jedna z nich, nebo prázdná množina, a v které existuje alespoň jedna dvojice podmnožin, které splňují tuto podmínku. Nehierarchické funguje na principu neprázdných podmnožin množiny X , v které nejsou průnikem každých dvou podmnožin ani jedna z nich [13] [9].

Jedním z hlavních problémů je určení podobnosti objektů a její kvantitativní vyjádření. Nejčastějším způsobem vyjádření podobnosti jsou metriky na základě geometrického modelu dat, např. výpočet euklidovské vzdálenosti mezi objekty [13].

$$\delta(r, s) = \left[\sum_{i=1}^p (x_{ri} - x_{si})^2 \right]^{\frac{1}{2}} \quad (4.4)$$


Obecně je metrika δ funkce definovaná na $E_p \times E_p$ přiřazující každé dvojici bodů (r, s) číslo $\delta(r, s)$ splňující tyto čtyři podmínky [13]:

$$\delta(r, s) = 0 \leftrightarrow r = s (\text{identita})$$

$$\delta(r, s) \geq 0$$

$$\delta(r, s) = \delta(s, r) (\text{symetrie})$$

$$\delta(r, t) \leq \delta(r, s) + \delta(s, t) (\text{trojuhelníková nerovnost})$$



Obrázek 11 Výsledky shlukování pro: a) správný počet shluků se všemi body správně klasifikovanými b) nesprávný počet shluků c) správný počet shluků, ale některé body nesprávně klasifikovány. Upraveno dle [16]

Výhodou metody shlukové analýzy je jednoduchost a snadná rozšiřitelnost. Výhodou je také velké množství modifikací. Výsledek je závislý na prvotním výběru center každé třídy. Nevýhodou je obtížný výběr počtu shluků a závislost výsledku segmentace na počátečním nastavení. Vstupními daty mohou být obrazová i objemová data [9] [15].

3.4.1 Algoritmus (K-means)

K-means je základním algoritmem metody shlukování. Úkolem je klasifikování bodů do konečného počtu shluků. Podmínkou je povinnost znát počet shluků před spuštěním. Algoritmus využívá Euklidovskou vzdálenost a μ_j to je aritmetický průměr bodu ve shluku – etanol. Prvním krokem je klasifikace, body se rozdělí do tříd podle minima euklidovské vzdálenosti. Klasifikováním se hledá minimální vzdálenost mezi bodem a těžištěm. Pixel je přiřazen do třídy podle následujícího vztahu, tedy vzor x_i je přiřazen do třídy y_i podle [13]:

$$y_i = \operatorname{argmin}_j ||x_i - \mu_j|| \quad (4.5)$$

Druhým krokem je přepočítání střední hodnoty bodů v daném shluku. Podle následujícího vztahu:

$$\mu_j = \frac{1}{l_j} \sum_{i=1, y_i=j}^l (x_i) \quad (4.6)$$

kde l_j je počet vzorů x_i klasifikovaných v druhém kroku do třídy určené vektorem μ_j .

Tyto dva kroky se opakují do té doby, než se bod klasifikuje do jiné třídy nebo než byl klasifikován v kroku před tím. Cílem je dosažení co nejmenších rozdílů hodnot jednotlivých bodů v třídě [13].

3.5 Závěr řešerše

V této kapitole bylo provedeno srovnání vybraných segmentačních metod a také byly zmíněny jejich výhody, nevýhody a využití. Algoritmy založené na prahování jsou citlivé na šum a je těžké je aplikovat na více kanálové obrazy. Proto se především využívají jako před segmentační krok. Metoda založená na růstu regionů měla problém s volbou výchozích bodů a počtem regionů. Byla také citlivá na obrazové artefakty a šum. U metody shlukování bylo hlavním problémem zvolení počtu shluků a místa výchozích bodů (těžišť). Moderní myšlenkou je pracovat s kombinací segmentačních metod. Kombinace metod by měla být zvolena podle konkrétní aplikace a objektu, který chceme detekovat. Hlavními schopnostmi segmentace by měla být účinnost, komplexnost a přesnost. Do budoucna by se měl vývoj segmentačních metod zaměřit na rychlost, efektivnost a omezení lidského faktoru [9] [11] [12].

4 Praktická část


Praktická část této bakalářské práce se bude popisovat aplikaci předzpracování mediánovou filtrací a segmentací metodami K-means a Otsu na předem zašumělá data. Budou použita obrazová data pořízená výpočetní tomografií a magnetickou rezonancí. Obsahem dat budou snímky cév, jater a chrupavek. Poté se na vyhodnocení procesu segmentace použijí vybrané evaluační parametry, pomocí kterých se zhodnotí jednotlivé metody. Použité evaluační parametry budou MSE, PSNR a index korelace.

4.1 Databáze medicínských obrazů

V této bakalářské práci se pracuje s obrazy, které byly pořízeny pomocí zobrazovacích systémů jako jsou výpočetní tomografie a magnetické rezonance. Data vyobrazují záznamy cévního systému, chrupavek a jater. Přesněji CT cév, CT jater, MRI chrupavky a MRI cév. Každá databáze obsahuje deset záznamů, to znamená, že je využito 40 snímků.

| Dataset | Počet snímků | Formát | Rozlišení | Bitová hloubka |
|-----------------|--------------|--------|-----------|----------------|
| CT – cévy | 10 | jpg. | 1024x1024 | 8 bit |
| CT – játra | 10 | jpg. | 630x630 | 8 bit |
| MRI – cévy | 10 | jpg. | 1024x1024 | 8 bit |
| MRI – chrupavky | 10 | png. | 512x512 | 8 bit |

Tabulka 1 Seznam použitých obrazových dat. Zdroj vlastní

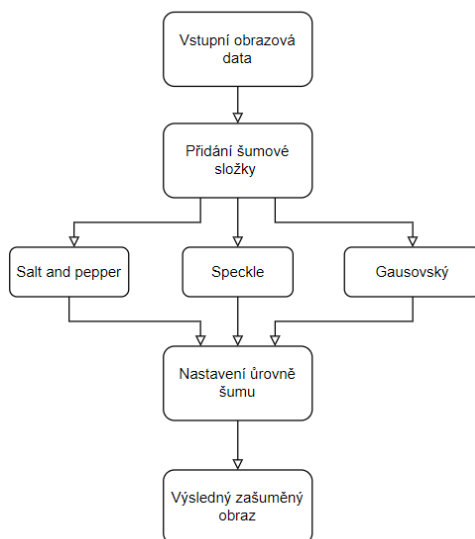


Obrázek 12 Ukázka použitých obrazových záznamů. Zleva snímek MRI-chrupavky, snímek CT-jater a MRI-cév.

Zdroj vlastní

4.2 Zašumění obrazu

K sledování efektivity předzpracování a metod segmentace v rámci variabilních obrazových podmínek musí být na vybraná obrazová data uměle přidán šum. Díky postupnému zvyšování úrovně šumu můžeme dobře sledovat vliv metod předzpracování a následné výsledky segmentace. Na obrazová data jsme použili tři druhy šumu: Gaussův, Speckle a Salt and Pepper.



Obrázek 13 Vývojový diagram aplikace šumu. Zdroj vlastní

Tabulka 2 Rozsah parametrů šumu. Zdroj vlastní

| Počet tříd | Typ šumu | | |
|------------|--|---------------------|------------------------|
| | Gaussův ($\sigma^2 = 0,01$), (μ) | Salt and Pepper (d) | Speckle (σ^2) |
| 3 | 0,01 – 0,1 | 0,01 – 0,1 | 0,04 – 0,4 |
| 5 | 0,01 – 0,1 | 0,01 – 0,1 | 0,04 – 0,4 |
| 10 | 0,01 – 0,1 | 0,01 – 0,1 | 0,04 – 0,4 |

4.2.1 Gaussův šum

Gaussův šum je nezávislý na signálu a jde o druh bílého šumu se stejnou mírou rozložení ve všech pixelech obrazu. Je to statistický šum s totožnou pravděpodobností výskytu jako je normální rozložení. Tento šum se používá jako nejbližší aproximační model reálného šumu. Na dále uvedeném obrázku je ukázka Gaussova šumu na jednom z testovaných obrazů, kdy byl vstupní originální snímek poškozen šumem. Šum je dán dvěma parametry rozptylem σ^2 a střením hodnotou μ . Hustota pravděpodobnosti Gaussova šumu se střední hodnotou μ a rozptylem σ^2 je dána vztahem [18]:


$$p_n(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{\sigma \frac{-(x-\mu)^2}{2\sigma^2}}, x \in (-\infty, \infty) \quad (5.1)$$



Obrázek 14 Srovnání Gaussova šumu u snímků chrupavky a cévního řečiště zleva nativní snímky, dále parametry $\sigma^2 = 0,1$ $\mu = 0,05$ a $\sigma^2 = 0,5$ $\mu = 0,05$. Zdroj vlastní

4.2.2 Salt and Pepper (šum sůl a pepř)


Šum Salt and Pepper, také nazýván impulsním nebo binárním šumem, je nezávislý na signálu a je tvořen náhodným výskytem černých a bílých pixelů. Většinou jde o situace, kde jsou postiženy jen některé pixely v obraze. Pixely se vyznačují zřetelně odlišnými hodnotami. Pixel může být buď bílý, nebo úplně černý, proto Sůl a Pepř. Parametrem šumu je denzita, např. $d=0,05$, která určuje, že 5 % pixelů v obraze bude nahrazeno bílou nebo černou. Příklad viz. níže záznam MRI cévy a MRI chrupavky [18].



Obrázek 15 Srovnání Salt and Pepper šumu na snímcích chrupavky a cévního řečiště zleva nativní snímky, dále parametry $d=0,1$ a $d=0,3$. Zdroj vlastní

4.2.3 Speckle šum

Jde o šum, který je závislý na signálu. “Speckle” šum, také nazýván granulární nebo interferenční šum, se modeluje pomocí násobení náhodného čísla s hodnotou obrazové funkce. Jde o multiplikativní šum, u kterého je definován parametr rozptylu σ^2 .



Obrázek 16 Srovnání Speckle šumu na snímcích chrupavky a cévního řečiště zleva nativní snímky, dále parametry $\sigma^2 = 0,1$ a $\sigma^2 = 0,3$. Zdroj vlastní

$$A = I + m \times I \quad (5.2)$$

Hodnota rozptylu 0 znamená že se v obraze nenachází žádný šum a hodnota 1 je pravým opakem, kdy je obraz 100 % postižen šumem [19].

4.3 Předzpracování obrazových dat

Pojmem předzpracování je myšleno upravení obrazu pro lepší analýzu, identifikaci objektů nebo jen pro lepší pozorování obrazu člověkem. To znamená upravit obraz tak, aby byl potlačen šum, odstraněno zkreslení a aby se potlačili či zvýraznili rysy v obraze. Kvalita předzpracování má velký vliv na výslednou segmentaci. V této práci budeme aplikovat filtraci pomocí mediánového filtru na předem zašuměná data a sledovat, jak filtr bude ovlivňovat výslednou segmentaci.

4.3.1 Mediánová filtrace

Mediánová filtrace je nelineární metoda nízkofrekvenční filtrace, která funguje na principu 2D diskrétní konvoluce. Použité filtrační jádro je o velikosti 5x5. Mediánová filtrace má dobré výsledky při potlačení černých a bílých bodů v obraze (Salt and Pepper). Medián je prostřední prvek v uspořádané posloupnosti hodnot.

$$\begin{pmatrix} 4 & 5 & 1 \\ 0 & 6 & 1 \\ 1 & 3 & 2 \end{pmatrix} \rightarrow (0 \ 1 \ 1 \ 1 \ 2 \ 3 \ 4 \ 5 \ 6) \rightarrow \begin{pmatrix} 4 & 5 & 1 \\ 0 & 2 & 1 \\ 1 & 3 & 2 \end{pmatrix}$$

Obrázek 17 Princip mediánového filtru




Obrázek 18 Srovnání použití mediánového filtru na Salt and Pepper šumu na snímcích chrupavky a cévního řečiště zleva nativní snímky, dále parametry $d=0,3$ a výsledek filtrace. Zdroj vlastní

Principem je posouvání okna masky po obraze a výběru mediánu z hodnot, které leží pod touto maskou. Metoda redukuje stupeň rozmazání hran a dobře potlačuje impulsní šum. Nevýhodou je, že porušuje tenké čáry a ostré rohy v obraze. Použitý filtr bude mít masku 5x5. Příklad výsledku použití filtru viz. obr. 17 [7].

4.4 Implemetace jednotlivých segmentačních metod

Celý proces segmentace se provádí v prostředí MATLAB. Hlavním cílem segmentace je extrakce objektů, např. rozeznání patologické tkáně od zdravé. Segmentace pracuje na principu separování objektů od nezajímavého pozadí. V této práci budeme testovat na vybraných medicínských datech metody prahování Otsu a shlukování pomocí algoritmu K-means. U každé metody bude použito různé nastavení parametrů.

4.4.1 Otsu prahování



Obrázek 19 Vývojový diagram Otsu prahování Zdroj vlastní

Otsu prahování je metoda prahování, při které se histogram obrazu rozdělí podle několika prahových hodnot intenzity jasu pixelů na počet oblastí podle předem zvoleného počtu. Tato metoda se snaží dosáhnout optimálních prahů tím, že snižuje společný rozptyl skupin bodů. Prahy jsou voleny tak, aby byl vážený součet rozptylů všech částí minimální. Je matematicky prokázáno, že minimalizace rozptylu uvnitř třídy je stejná jako maximalizace rozptylu mezi třídami. Vážený součet je definovaný následující rovnicí [20]:

$$\sigma_{\omega}^2(t) = \omega_0(t) \cdot \sigma_0^2(t) + \omega_1(t) \cdot \sigma_1^2(t), \quad (5.3)$$

$\omega_0(t)$ je pravděpodobnost výskytu intenzit menších než t


$\omega_1(t)$ je pravděpodobnost výskytu intenzit větších než t

$$\omega_0(t) = \sum_{i=0}^{t-1} p(i)$$

$\omega_1(t) = \sum_{i=t}^{L-1} p(i)$, kde $L - 1$ je počet úrovní intenzit v obraze

$\sigma_0(t)$ je rozptyl intenzit menších než t

$\sigma_1(t)$ je rozptyl intenzit větších než t

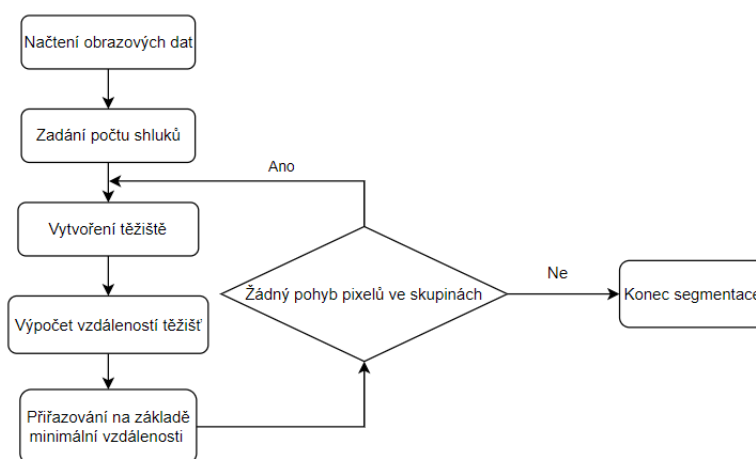


Obrázek 20 Srovnání použití Otsu metody na snímky MRI cév a MRI chrupavky. Zleva nativní snímky, 3 segmentované oblasti a 5 segmentovaných oblastí. Zdroj vlastní

Na segmentovaném obrazu můžeme vidět lepší oddělení jednotlivých oblastí a poměrně velké zvýraznění silně prokrvených částí např. cév u prvního segmentovaného obrazu.

4.4.2 Shlukování pomocí K-means

Hlavním úkolem metody je v množině objektů identifikovat její podmnožiny. To znamená přiřadit vektor, který bude reprezentovat nějaký pixel určité oblasti (shluku).




Obrázek 21 Vývojový diagram shlukování K-means. Zdroj vlastní

K-means je základní algoritmus shlukování. Úkolem je klasifikování bodů do konečného počtu shluků. Podmínkou je povinnost znát počet shluků před spuštěním. Algoritmus využívá Euklidovskou vzdálenost a μ_j aritmetický průměr bodu ve shluku – etanol. Prvním krokem je klasifikace, body se

rozdělí do tříd podle minima euklidovské vzdálenosti. Klasifikováním se hledá minimální vzdálenost mezi bodem a těžištěm. Algoritmus K-means funguje na principu s tvrdým přístupem. To znamená že jednotlivý bod buď patří do shluku, anebo ne [13].

Algoritmus metody:

1. Volba počtu shluků.
2. Náhodné rozdělení bodů do shluků.
3. Určení jednotlivých těžišť.
4. Určení vzdálenosti všech bodů od těžišť.
5. Přidělení bodů do shluků na základě vzdáleností do těžišť.
6. Opakování cyklu, dokud se přidělování nestane stabilním.



Obrázek 22 Srovnání použití shlukování K-means na snímky MRI cév a MRI chrupavky. Zleva nativní snímky, 3 shluky a 5 shluků. Zdroj vlastní

4.5 Evaluační parametry pro analýzu podobnosti

V této práci se pro kvalitní hodnocení a srovnání výsledků předzpracování a segmentace využije analýza podobnosti pomocí vybraných evaluačních parametrů. Na porovnání výsledných dat se použije střední kvadratická chyba, korelační koeficient a špičkový odstup od šumu. Pomocí těchto parametrů se budou hodnotit finální výsledky.

4.5.1 Střední kvadratická chyba (MSE)

MSE (Mean Squared Error). Střední kvadratická chyba je nejjednodušší a nejpoužívanější metodou pro hodnocení kvality obrazu. Pro dvourozměrný obrazový signál je definována takto:

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (X_{i,j} - Y_{i,j})^2, \quad (5.4)$$

kde $X_{i,j}$ a $Y_{i,j}$ představují hodnoty jasu u šedo tónového obrazu o rozměrech $M \times N$. Jestli je hodnota $X_{i,j}$ považována za hodnotu originálního obrazu, pak rozdíl mezi hodnotou $Y_{i,j}$ je chybný obrazový signál. Jestli je hodnota MSE rovna nula, pak jsou obrazy totožné. Metoda porovnává obraz pixel po pixelu [21].

4.5.2 Špičkový odstup od šumu (PSNR)

Špičkový poměr signálu k šumu je jedním z nejdůležitějších parametrů k určení kvality obrazu. PSNR vychází z výpočtu hodnoty MSE. A vyjadřuje poměr mezi maximální energií pixelu v obraze a energií šumu. Vyšší hodnota značí kvalitnější obraz. PSNR je vyjádřeno v jednotkách decibelech [dB] Rovnice má následující tvar:

$$PSNR = 10 \cdot \log_{10} \frac{\sum_{i=1}^M \sum_{j=1}^N (X_{i,j} - Y_{i,j})^2}{\sum_{i=1}^M \sum_{j=1}^N (X_{i,j} - Y_{i,j})^2}, \quad (5.5)$$

kde $X_{i,j}$ a $Y_{i,j}$ představují hodnoty jasu originálního a zkušebního obrazu [21].

4.5.3 Korelační koeficient

Pojem „korelace“ znamená ve statistice vzájemný lineární vztah mezi dvěma veličinami. Míru této korelace vyjadřuje korelační koeficient, který může nabývat hodnot od -1 po +1 včetně. Výsledný korelační koeficient získáme při poměru kovariance proměnných vynásobených jejich směrodatnými odchylkami. Nulová korelace nastane v případě, kdy mezi veličinami X a Y není žádná lineární závislost.

$$r = \frac{\sum (x_i - \bar{x}) \cdot (y_i - \bar{y})}{(n-1) s_x s_y} \quad (5.6)$$


kde s_x a s_y jsou směrodatné odchylky a x, y jsou aritmetické průměry jednotlivých proměnných. čím jsou si signály podobnější tím je hodnota koeficientu blíží jedné [21].

4.6 Testování metod na medicínských datech


V této kapitole jsou uvedeny jen reprezentativní ukázky grafů a výsledných hodnot pro zhodnocení testovaných metod, které jsou v této práci zkoumané. Zbylé materiály, pomocí kterých bylo provedeno zhodnocení, jsou součástí příloh z důvodu velkého množství výstupních materiálů.

4.6.1 Výsledky CT-cévy

Pro ukázku jsou níže uvedeny příklady segmentace metodou K-means shlukování a Otsu prahování na předem zašuměné snímky z oblasti CT-cévy. Příklady jsou znázorněné na snímcích poškozených Gaussovým šumem a při segmentaci do tří oblastí. Ostatní výsledky segmentace jsou v příloze této práce.




Obrázek 23 Ukázka použití shlukování K-means do třech oblastí na snímek CT cév. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Gaussovým šumem. Zdroj vlastní




Obrázek 24 Ukázka použití prahování Otsu do třech oblastí na snímek CT cév. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Gaussovým šumem. Zdroj vlastní

Dále jsou uvedeny grafy průběhů evaluačních parametrů, pomocí kterých byla provedena analýza výkonnosti segmentace v závislosti na počtu segmentovaných tříd. V níže uvedených grafech je vizualizován průběh jednotlivých parametrů (MSE, PSNR a indexu korelace) při postupném zvyšování intenzity šumu u obou testovaných metod. Na ukázkou jsou použity jen grafy, které nejlépe reprezentovali daný trend. Zbylé grafy jsou k nalezení v příloze této práce.



Obrázek 25 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody K-means. Snímky CT-cévy. Typ šumu Salt and Pepper. Zdroj vlastní


V uvedených grafech lze sledovat postupné zmenšování kvality obrazu v závislosti na intenzitě šumu u všech sledovaných parametrů. U indexu korelace jako jediného vychází kvalita segmentovaného obrazu lépe při segmentaci do 10 shluků a postupně klesá při segmentování do menšího počtu shluků. Hodnota parametru střední kvadratické chyby (MSE) naopak výrazně roste při segmentaci do 10 shluků. Parametr PSNR potvrzuje vyšší kvalitu obrazu při segmentaci do menšího počtu shluků a postupně klesá s větším počtem segmentovaných oblastí. S uvedených průběhů můžeme vyhodnotit lepší výsledky metody K-means při segmentaci do menšího počtu shluků.



Obrázek 26 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody Otsu. Snímky CT-cévy. Typ šumu Speckle. Zdroj vlastní


Výsledky testování u metody Otsu vychází podobně jako u metody K-means. Hodnoty PSNR i MSE značí větší kvalitu výsledného obrazu při segmentaci do menšího počtu segmentovaných tříd. Index korelace naopak ukazuje horší výsledky testování u segmentace do menšího počtu tříd. Z výsledných hodnot lze vyčíst přesnější výsledek segmentace u menšího počtu segmentovaných oblastí.

Níže jsou uvedeny grafy, které pomocí výsledných hodnot testování porovnávají kvalitu obrazu mezi jednotlivými metodami Otsu a K-means. Při segmentaci do tří regionů a u zašumění typu Salt and Pepper.



Obrázek 27 Srovnání mediánu evaluačních parametrů metod Otsu a K-means. Typ šumu Salt and Pepper. Snímky CT-cévy. Při segmentaci do 3 segmentačních tříd. Zdroj vlastní

Z výše uvedených grafů, které porovnávají kvalitu mezi testovanými metodami Otsu a K-means, lze vyčíst, že lepší výsledky testování vychází při segmentaci metodou K-means. Všechny tři parametry (MSE, PSNR a index korelace) ukazují lepší výsledné hodnoty evaluačních parametrů u metody K-means.




Obrázek 28 Srovnání mediánu evaluačních parametrů mezi segmentací s použitím filtru a bez. Typ šumu Gauss. Snímky CT-cévy. Při segmentaci do 10 segmentačních tříd. Zdroj vlastní


V posledním hodnocení výsledků databáze CT-cévy je hodnocen vliv filtru na výslednou segmentaci. Výhodné použití filtru ukazují parametry indexu korelace i MSE, které ukazují nejen lepší hodnoty oproti segmentaci bez filtru, ale také stabilnější výsledky při postupném zvyšování intenzity šumu, především při segmentaci do menšího počtu regionů. Horší výsledek kvality ukazuje jen parametr PSNR, který značí vyšší kvalitu u nefiltrovaných obrazů.

4.6.2 Výsledky MRI-cévy

Pro ukázkou jsou níže uvedeny příklady segmentace metodou K-means shlukování a Otsu prahování na předem zašuměné snímky z oblasti MRI-cévy. Příklady jsou znázorněné na snímcích poškozenými Speckle šumem a při segmentaci do tří oblastí. Ostatní výsledky segmentace jsou v příloze této práce.




Obrázek 29 Ukázka použití shlukování K-means do třech oblastí na snímek MRI cév. Z leva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Speckle šumem. Zdroj vlastní




Obrázek 30 Ukázka použití prahování Otsu do třech oblastí na snímek MRI cév. Z leva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Speckle šumem. Zdroj vlastní

Dále jsou uvedeny výsledky testování, které byly použity pro hodnocení jednotlivých metod, aplikovaných na databázi MRI-cévy. Příklady výsledků budou reprezentovat jen grafy, které nejlépe vizualizovali daný trend. Ostatní výsledky analýzy všech evaluačních parametrů jsou v příloze této práce.




Obrázek 31 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody K-means. Snímky MRI-cévy. Typ šumu Salt and Pepper. Zdroj vlastní

Ve výše uvedených analýzách je zobrazen průběh jednotlivých parametrů v závislosti na intenzitě šumu. U indexu korelace vychází kvalita testovaného obrazu nejhůře při segmentaci obrazu do 3 shluků. Hodnota parametru střední kvadratické chyby (MSE) výrazně roste při segmentaci do 10 shluků. Parametr PSNR potvrzuje vyšší kvalitu obrazu při segmentaci do menšího počtu shluků. A postupně klesá s větším počtem segmentovaných oblastí. Z uvedených průběhů můžeme vyhodnotit lepší výsledky metody K-means při segmentaci do menšího počtu shluků.




Obrázek 32 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody Otsu. Snímky MRI-cévy. Typ šumu Salt and Pepper. Zdroj vlastní

U metody Otsu průběhy parametrů značí jasně větší kvalitu obrazu při segmentaci do menšího počtu regionů. Největší rozdíl hodnot je viditelný u parametru MSE, kdy při segmentaci do 10 oblastí hodnota výrazně roste oproti ostatním nastavením. U indexu korelace a PSNR hodnoty postupně klesají s větším počtem segmentovaných oblastí.



Obrázek 33 Srovnání mediánu evaluačních parametrů metod Otsu a K-means. Snímky MRI-cévy. Typ šumu Salt and Pepper. Při segmentaci do 3 segmentačních tříd. Zdroj vlastní

Porovnání obou metod u snímků MRI-cév se podstatně liší oproti analýze z oblasti CT. Index korelace u Otsu metody ukazuje větší podobnost snímků oproti K-means. MSE (střední kvadratická chyba) také značí vyšší kvalitu obrazu u Otsu metody a parametr PSNR potvrzuje lepší výsledky analýzy u metody Otsu.




Obrázek 34 Srovnání mediánu evaluačních parametrů mezi segmentací s použitím filtru a bez. Typ šumu Gauss. Snímky MRI-cévy. Při segmentaci do 10 segmentačních tříd. Zdroj vlastní


V posledním hodnocení výsledků databáze MRI-cévy je hodnocen vliv filtru na výslednou segmentaci. Výhodné použití filtru ukazují parametry indexu korelace i MSE. Horší výsledek kvality ukazuje jen parametr PSNR, který značí vyšší kvalitu u nefiltrovaných obrazů. Tento výsledek parametru PSNR vychází hlavně při segmentaci obrazů do většího počtu regionů.

4.6.3 Výsledky CT-játra

Pro ukázkou jsou níže uvedeny příklady segmentace metodou K-means shlukování a Otsu prahování na předem zašuměné snímky z oblasti CT-játra. Příklady jsou znázorněné na snímcích poškozených Gaussovým šumem a při segmentaci do tří oblastí. Ostatní výsledky segmentace jsou v příloze této práce.




Obrázek 35 Ukázka použití shlukování K-means do třech oblastí na snímek CT-játra. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Salt and Pepper šumem. Zdroj vlastní




Obrázek 36 Ukázka použití prahování Otsu do třech oblastí na snímek CT-játra. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Salt and Pepper šumem. Zdroj vlastní

Dále jsou uvedeny výsledky testování, které byly použity pro hodnocení jednotlivých metod, aplikovaných na databázi CT-játra. Příklady výsledků budou reprezentovat jen grafy, které nejlépe vizualizovali daný trend. Ostatní výsledky analýzy všech evaluačních parametrů jsou v příloze této práce. Porovnávání budou počty segmentovaných regionů, metody mezi sebou a segmentace s využitím předzpracování a bez.




Obrázek 37 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody K-means. Snímky CT-játra. Typ šumu Salt and Pepper. Zdroj vlastní

Výsledky testování databáze CT-játra. Při porovnávání vlivu počtu shluků na výsledek segmentace u metody K-means vychází podobně jako při testování u ostatních databází. U indexu korelace vychází kvalita testovaného obrazu nejhůře při segmentaci obrazu do 3 shluků. Hodnota parametru střední kvadratické chyby (MSE) výrazně roste při segmentaci do 10 shluků. Parametr PSNR potvrzuje vyšší kvalitu obrazu při segmentaci do menšího počtu shluků a postupně klesá s větším počtem segmentovaných oblastí. Z uvedených průběhů můžeme vyhodnotit lepší výsledky metody K-means při segmentaci do menšího počtu shluků.




Obrázek 38 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody Otsu. Snímky CT-játra. Typ šumu Salt and Pepper. Zdroj vlastní

Při testování vlivu počtu segmentovaných regionů na výslednou kvalitu obrazu u metody Otsu je jasně viditelný výsledek parametru MSE, u kterého chyba výrazně roste při segmentaci do 10 oblastí. Také parametr PSNR ukazuje postupné zhoršování kvality obrazu při vyšším počtu segmentovaných oblastí.



Obrázek 39 Srovnání mediánu evaluačních parametrů metod Otsu a K-means. Typ šumu Salt and Pepper. Snímky CT-játra. Při segmentaci do 10 segmentačních tříd. Zdroj vlastní

Z výše uvedených grafů, které porovnávají kvalitu mezi testovanými metodami Otsu a K-means, lze vyčíst, že lepší výsledky testování vychází při segmentaci metodou K-means. Parametry MSE, PSNR a index korelace ukazují lepší výsledné hodnoty u metody K-means.




Obrázek 40 Srovnání mediánu evaluačních parametrů mezi segmentací s použitím filtru a bez. Typ šumu Gauss. Snímky CT-játra. Při segmentaci do 3 segmentačních tříd. Zdroj vlastní


V posledním hodnocení výsledků databáze CT-játra je hodnocen vliv filtru na výslednou segmentaci. Výhodné použití filtru ukazují parametry indexu korelace i MSE, které ukazují nejen lepší hodnoty oproti segmentaci bez filtru, ale také stabilnější výsledky při postupném zvyšování intenzity šumu, především při segmentaci do menšího počtu regionů. U filtrovaných obrazů vychází lépe i parametr PSNR.

4.6.4 Výsledky MRI-chrupavky

V níže uvedených příkladech jsou ukázky výsledné segmentace obou metod na obrazy MRI-cévy. Jako příklad jsou porovnány nativní snímky, segmentované snímky a segmentované snímky poškozené šumem Speckle. Ostatní výsledky segmentace jsou v příloze této práce.




Obrázek 41 Ukázka použití shlukování K-means do třech oblastí na snímek MRI-chrupavky. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Speckle šumem. Zdroj vlastní




Obrázek 42 Ukázka použití prahování Otsu do třech oblastí na snímek CT-játra. Zleva nativní snímek, segmentace nativního snímku a segmentace snímku poškozeného Speckle šumem. Zdroj vlastní

Dále jsou uvedeny výsledky testování, které byly použity pro hodnocení jednotlivých metod, aplikovaných na databázi MRI-chrupavky. Příklady výsledků budou reprezentovat jen grafy, které nejlépe vizualizovaly daný trend. Ostatní výsledky analýzy všech evaluačních parametrů jsou v příloze této práce.




Obrázek 43 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody K-means. Snímky MRI-chrupavky. Typ šumu Gauss. Zdroj vlastní

Ve výše uvedených analýzách je zobrazen průběh jednotlivých parametrů v závislosti na intenzitě šumu. U indexu korelace vychází kvalita testovaného obrazu nejhůře při segmentaci obrazu do 3 shluků. Hodnota parametru střední kvadratické chyby (MSE) výrazně roste při segmentaci do 10 shluků. Parametr PSNR potvrzuje větší kvalitu obrazu při segmentaci do menšího počtu shluků. A postupně klesá s větším počtem segmentovaných oblastí. Z uvedených průběhů můžeme vyhodnotit lepší výsledky metody K-means při segmentaci do menšího počtu shluků.




Obrázek 44 Srovnání mediánu evaluačních parametrů podle počtu segmentovaných oblastí u metody Otsu. Snímky MRI-chrupavky. Typ šumu Gauss. Zdroj vlastní

Výsledky testování u metody Otsu vychází podobně jako u metody K-means. Hodnoty PSNR i MSE značí větší kvalitu výsledného obrazu při segmentaci do menšího počtu regionů. Index korelace naopak ukazuje horší výsledky testování u segmentace do menšího počtu regionů. Z výsledných hodnot lze vyčíst přesnější výsledek segmentace u menšího počtu segmentovaných oblastí.



Obrázek 45 Srovnání mediánu evaluačních parametrů metod Otsu a K-means. Typ šumu Speckle. Snímky MRI-chrupavky. Při segmentaci do 3 segmentačních tříd. Zdroj vlastní

V testování účinnosti obou metod mezi sebou ukazují výsledky databáze MRI-chrupavky vyšší kvalitu segmentace při použití K-means. Parametry indexu korelace i MSE mají lepší výsledek u K-means. Parametr PSNR zase značí vyšší kvalitu obrazu u metody Otsu, ale jen při segmentaci s malou intenzitou šumu. Při vyšší intenzitě má lepší výsledky metoda K-means.



Obrázek 46 Srovnání mediánu evaluačních parametrů mezi segmentací s použitím filtru a bez. Typ šumu Speckle. Snímky MRI-chrupavky. Při segmentaci do 5 segmentačních tříd. Zdroj vlastní

V posledním hodnocení výsledků databáze MRI-chrupavky je hodnocen vliv filtru na výslednou segmentaci. Výhodné použití filtru ukazují parametry indexu korelace i MSE, které ukazují nejen lepší hodnoty oproti segmentaci bez filtru, ale také stabilnější výsledky při postupném zvyšování intenzity šumu. Hlavně při segmentaci do menšího počtu regionů. Segmentací filtrovaných obrazů do menšího počtu regionů lépe vychází i parametr PSNR. S vyšším počtem regionů hodnota PSNR u filtrovaných obrazů znatelně klesá.

4.6.5 Vyhodnocení testování

V této bakalářské práci byla hlavním cílem analýza vybraných segmentačních metod. Konkrétně se testoval vliv počtu segmentačních regionů, kvalita výsledků jednotlivých metod a vliv předzpracování na výslednou segmentaci. Testování proběhlo na snímky pořízené zobrazovacími metodami CT a MRI. Snímky byly uměle poškozeny šumem typu Gauss, Salt and Pepper a Speckle. Poté proběhlo testování jednotlivých metod na vybrané obrazy. Dosažené výsledky byly hodnocené pomocí evaluačních parametrů (MSE, PSNR a indexu korelace).

Ve všech testovaných databázích lze sledovat postupné zmenšování kvality obrazu v závislosti na intenzitě šumu u všech sledovaných parametrů. U indexu korelace jako jediného vychází kvalita segmentovaného obrazu lépe při segmentaci do 10 regionů a postupně klesá při segmentování do menšího počtu regionů. Hodnota parametru střední kvadratické chyby (MSE) naopak výrazně roste při segmentaci do 10 regionů. Poslední parametr PSNR potvrzuje vyšší kvalitu obrazu při segmentaci do menšího počtu regionů a postupně klesá s větším počtem segmentovaných oblastí. Ze všech testovaných parametrů můžeme vyhodnotit lepší výsledky obou metod při segmentaci do menšího počtu regionů.

U testování metod Otsu a K-means mezi sebou byly výsledky znatelně rozdílné, hlavně v závislosti na zobrazovací metodě, kterou byly testované obrazy pořízeny. U snímků pořízených pomocí CT, měla lepší výsledky metoda K-means. Při segmentaci obrazu značily všechny parametry vyšší kvalitu u K-means. Celkově měla u obrazů pořízených pomocí CT lepší výsledky metoda K-means. U obrazů pořízených pomocí MRI byly výsledky obou databází rozdílné. V testování databáze MRI-cév značily všechny parametry vyšší kvalitu segmentace při použití metody Otsu. Naopak u snímků MRI-chrupavky výsledky ukazovaly vyšší kvalitu při segmentaci metodou K-means. Ze všech testování lze určit, že výsledky obou metod segmentace jsou závislé na zobrazovací metodě, kterou byly dané snímky pořízeny.

V posledním testování byl hodnocen vliv filtru na výslednou segmentaci. Výhodné použití filtru značily parametry indexu korelace i MSE. Ukázaly nejen lepší výsledky oproti segmentaci bez filtru, ale také stabilnější hodnoty při postupném zvyšování intenzity šumu. Hlavně při segmentaci obrazu do menšího počtu regionů. Také parametr PSNR vycházel lépe při segmentaci filtrovaných obrazů do menšího počtu regionů. S vyšším počtem regionů parametr PSNR u filtrovaných obrazů znatelně klesal. Z dosažených výsledků je zřetelné, že vyšší kvality obrazu dosáhly snímky, na které bylo použito předzpracování pomocí mediánového filtru.

Závěr

Hlavním cílem této bakalářské práce byla analýza vybraných segmentačních metod. Konkrétně se testoval vliv počtu segmentačních regionů, kvalita výsledků jednotlivých metod vzájemně mezi sebou a vliv předzpracování na výslednou segmentaci. Testování proběhlo na snímcích pořízených zobrazovacími metodami CT a MRI. Obsahem záznamů byly cévy, chrupavky a játra.

Počáteční fází této práce bylo teoretické seznámení se se základy zpracování obrazu, a to od pořízení obrazových dat, až po samotnou klasifikaci. Hlavní náplní teorie bylo předzpracování a segmentace obrazu. U metod předzpracování byly hlavně rozebrány jasové transformace, geometrické transformace a filtrace obrazů. Dále práce pokračovala řešením regionově orientovaných metod segmentace, ve které byly nastudovány důležité vlastnosti, nedostatky a výhody jednotlivých technik. Zkoumané byly hlavně metody prahování a shlukování z důvodů využití v praktické části práce.

Praktická část práce začala vytvořením jednotlivých databází (MRI-cévy, MRI-chrupavky, CT-játra a CT-cévy) z přidělených medicínských obrazů. Každá databáze obsahovala 10 obrazů, na které byly uměle aplikovány tři druhy šumu (Gaussovský, Salt and Pepper a Speckle). U každého šumu bylo vytvořeno 10 úrovní. Všechna jednotlivá data poškozená šumem byla uložena a použita na testování předzpracování a segmentace. Obsahem testování bylo zhodnocení vlivu počtu regionů jednotlivých metod, porovnání výkonnosti obou metod mezi sebou a vliv mediánového filtru na výsledek segmentace. Výsledky segmentace byly hodnoceny pomocí vybraných evaluačních parametrů. Použity byly parametry: index korelace, střední kvadratická chyba (MSE) a odstup signálu od šumu (PSNR). Ve všech testovaných databázích bylo možné sledovat postupné zmenšování kvality obrazu v závislosti na intenzitě šumu u všech sledovaných parametrů. Při sledování vlivu počtů regionů výsledky ukázaly větší kvalitu výsledného obrazu při segmentaci do menšího počtu regionů. U testování metod Otsu a K-means mezi sebou, byly výsledky znatelně rozdílné, hlavně v závislosti na zobrazovací metodě, kterou byly testované obrazy pořízeny. Při testování CT snímků značily všechny parametry vyšší kvalitu u K-means. V testování databáze MRI-cévy značily všechny parametry vyšší kvalitu segmentace při použití metody Otsu. Naopak u snímků MRI-chrupavky výsledky ukazovaly vyšší kvalitu při segmentaci metodou K-means. Ze všech testování lze určit, že výsledky obou metod segmentace jsou závislé na zobrazovací metodě, kterou byly dané snímky pořízeny. V posledním testování byl hodnocen vliv filtru na výslednou segmentaci. Výhodné použití filtru značily parametry indexu korelace i MSE. Ukázaly nejen lepší výsledky oproti segmentaci bez filtru, ale také stabilnější hodnoty při postupném zvyšování intenzity šumu. Hlavně při segmentaci obrazu do menšího počtu regionů. Z dosažených výsledků bylo zřetelné, že vyšší kvality obrazu dosáhly snímky, na které bylo použito předzpracování pomocí mediánového filtru.

Závěrem práce byla tvorba laboratorní úlohy. Součástí úlohy byla aplikace jednotlivých druhů šumu na načtené obrazy. Poté se na obrazy aplikovalo předzpracování a segmentace. Všechny výsledky se porovnály pomocí evaluačních parametrů a uložily do tabulky. V závěru protokolu se zhodnotily dosažené výsledky.

Literatura

- [1] Hájovský, R., Pustková, R., Kutálek, F.: Zpracování obrazu v měřící a řídicí technice, Ostrava 2012, ISBN 978-80-248-2596-0.
- [2] Hlaváč, V., Sedláček, M.: Zpracování signálů a obrazů, skripta ČVUT Praha, Vydavatelství ČVUT Praha 2005, ISBN 80-01-03110-1.
- [3] JAN, Jiří. Medical image processing, reconstruction and restoration: concepts and methods. BocaRaton: Taylor & Francis, 2006. Signal processing and communications, 25. ISBN0-8247-5849-8.
- [4] Sojka, E.: Digitální zpracování a analýza obrazu, skripta VŠB-TU Ostrava, Vydavatelství VŠB-TU Ostrava 2000, ISBN 80-7078-746-5.
- [5] Digitalizace a zpracování obrazu. [online]. <http://home.zcu.cz/>. [cit.5.11.2020]. Dostupný z WWW: <<http://home.zcu.cz/~holota5/publ/DigZprO.pdf>>
- [6] KUBÍČEK, Jan. Zpracování medicínských obrazových dat. Opava: Slezská univerzita v Opavě, Filozoficko-přírodovědecká fakulta, Ústav fyziky, 2014. ISBN 978-807-2489-411.
- [7] GONZALEZ, Rafael C., Richard E. WOODS a Steven L. EDDINS. Digital Image processing using MATLAB. Upper Saddle River, NJ: Pearson/Prentice Hall, c2004. ISBN 0-13-008519-7.
- [8] HOZMAN, Jan. Základní metody předzpracování obrazu [online]. ČVUT Praha, , 1-28 [cit. 2020-11-05]. Dostupné z: http://webzam.fbmi.cvut.cz/hozman/Zprac_obr_prisp_kurz_UEM_3_2003.pdf
- [9] ŠPANĚL, M., BERAN, V. Obrazové segmentační techniky. Vysoké učení technické v Brně [online]. poslední revize 19.ledna 2006. [8. 11. 2020].
- [10] SRIDEVI, S a M SUNDARESAN. Survey of image segmentation algorithms on ultrasound medical images. 2013 International Conference on Pattern Recognition: Informatics and Mobile Engineering [online]. 2013, 215-220 [cit. 2020-11-10]. Dostupné z: doi:10.1109 / ICPRIME.2013.6496475
- [11] ELAYARAJA, P a M SUGANTHI. Survey on Medical Image Segmentation Algorithms. International Journal of Advanced Research in Computer and Communication Engineering [online]. 2014 [cit. 2020-11-10]. ISSN 2278-1021. Dostupné z: <https://pdfs.semanticscholar.org/32a5/09d38daa14760ac272b2e2208a8583160ba8.pdf>
- [12] MA, Zhen, R. M. Natal JORGE a João MANUEL R. S. TAVARES. A Review on the Current Segmentation Algorithms for Medical Images.. Porto. University of Porto [online]. 2009 [cit. 2020-11-10]. Dostupné z: <https://hdl.handle.net/10216/7125>
- [13] KELBEL, J., ŠILHÁN, D. Shluková analýza. Laboratoř biokybernetiky [online]. poslední revize 19.října 2005. [citováno 11. 11. 2012].
- [14] V. Hlaváč, M. Šonka: Počítačové vidění. Vydavatelství Grada, Praha, ČR, 1992.
- [15] Alsabti, S., Khaled; Ranka; Singh, V.: An efficient k-means clustering algorithm. Electrical Engineering and Computer Science. Paper 43., 2009.
- [16] PASÁČEK, Václav. Segmentace obrazu podle textury [online]. Brno, 2012 [cit. 2019-09-21]. Dostupné z: <https://dSPACE.vutbr.cz/xmlui/bitstream/handle/11012/53606/13480.pdf?sequence=2&isAllowed=y>. Diplomová práce. Vysoké učení technické v Brně.

- [17] ŽELEZNÝ, Miloš. *Strukturální metody rozpoznávání* [online]. [cit. 2020-12-08]. Dostupné z: <http://www.kky.zcu.cz/uploads/courses/smr/Smr-130924.pdf>
- [18] DOUGHERTY, Geoff. *Digital image processing for medical applications*. New York: Cambridge University Press, 2009. ISBN 978-0-521-86085-7
- [19] HUA, Cheng a Tian JINWEN. Speckle Reduction of Synthetic Aperture Radar Images Based on Fuzzy Logic. In: 2009 First International Workshop on Education Technology and Computer Science [online]. IEEE, 2009, 2009, s. 933-937 [cit. 2021-03-21]. DOI: 10.1109/ETCS.2009.212. ISBN 978-0-7695-3557-9. Dostupné z: <http://ieeexplore.ieee.org/document/4958916/>
- [20] BIRDAL, T., Famous Otsu Thresholding in C#, The Code Project, [online] červenec 2009 [cit. 21. 3. 2021] dostupné z <https://www.codeproject.com/Articles/38319/Famous-Otsu-Thresholding-in-C>
- [21] WINKLER, Stefan.: *Digital video quality, Vision Models and Metrics*, London, Wiley, 2005, ISBN 0-47002404-6, s. 54.
- [22] KALOVÁ, Ilona. Segmentace a detekce geometrických primitiv [online]. [cit. 2021-03-21]. Dostupné z: http://vision.uamt.feec.vutbr.cz/POV/lectures/05_Segmentace.pdf
- [23] Horák, Karel. Jasové transformace [online]. [cit. 2021-03-21]. Dostupné z: <https://docplayer.cz/122059110-Jasove-transformace-karel-horak-rozvrh-prednasky.html>
- [24] Hlaváč, Václav a Kybic, Jan. Jasové transformace. Fakulta elektrotechnická ČVUT v Praze katedra kybernetiky, Centrum strojového vnímání [online]. [cit. 2021-03-21]. Dostupné z: https://cw.fel.cvut.cz/old/_media/courses/a6m33zmo/jasovetransformace.pdf

Seznam příloh

Laboratorní úloha:

Součástí příloh je návrh protokolu edukativní laboratorní úlohy, který obsahuje zadání a postup pro vypracování úlohy.

Kódy a algoritmy:

V přílohách jsou uloženy kódy na analýzu všech metod použitých v práci. Kódy obsahují načtení snímků, aplikaci šumů, filtraci mediánovým filtrem, segmentaci metodami Otsu a K-means a hodnocení evaluačními parametry.

Data:

Přílohy obsahují všechny načtené snímky, zašuměné snímky, segmentované obrazy a výsledné evaluační parametry všech testovaných metod. Data jsou rozdělená do složek podle databází:

- MRI – cévy
- MRI-chrupavky
- CT-játra
- CT-cévy

Grafy:

Zde se nachází všechny grafy obsahující analýzu testování a jsou rozdělené do složek podle databází:

- MRI – cévy
- MRI-chrupavky
- CT-játra
- CT-cévy

Bakalářská práce:

Zde je uložen textový soubor práce.